

*TEMPORAL FUSION TRANSFORMERS PARA LA
PREDICCIÓN DEL TÉRMINO DE FACTURACIÓN PVPC*

*TEMPORAL FUSION TRANSFORMERS (TFT) FOR THE
PREDICTION OF THE PVPC BILLING TERM*

Víctor GARCÍA-CHICO¹, Manuel RAMOS-JIMÉNEZ², Lucía RIERA-PRESMANES³, Roberto SALAMANCA-BARRIOS⁴, y Ana Belén GIL GONZÁLEZ⁵

¹ *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ victorgarciachico@usal.es

🌐 <https://orcid.org/0009-0001-4834-2697>

² *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ manuelramosji@usal.es

🌐 <https://orcid.org/0009-0006-2852-1766>

³ *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ luripres@usal.es

🌐 <https://orcid.org/0009-0006-7254-6311>

⁴ *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ robertosala@usal.es

🌐 <https://orcid.org/0009-0007-2318-6054>

⁵ *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ anabg@usal.es

🌐 <https://orcid.org/0000-0001-7235-6151>

RESUMEN: La creciente volatilidad del mercado eléctrico, impulsada por la penetración de fuentes renovables, exige modelos de predicción de precios (EPF) precisos para garantizar una gestión energética eficiente en el sector residencial. Este trabajo aborda la predicción a corto plazo (horizonte 24 horas) de la tarifa regulada española (PVPC) mediante la arquitectura *Temporal Fusion Transformer* (TFT), diseñada para capturar dependencias temporales complejas manteniendo la interpretabilidad. Utilizando datos reales de 2024, se evalúa el desempeño del modelo propuesto frente a redes LSTM y métodos de persistencia. Los resultados experimentales demuestran la superioridad del TFT, logrando un MAE de 30.63 €MWh y un sMAPE de 0.1838, lo que representa una reducción del error del 28.7 % respecto a la arquitectura LSTM convencional.

Palabras clave: predicción de precios de electricidad (EPF); PVPC; Temporal Fusion Transformer (TFT); *deep learning*; series temporales; gestión energética.

ABSTRACT: The increasing volatility of the electricity market, driven by the penetration of renewable energy sources, requires accurate Electricity Price Forecasting (EPF) models to ensure efficient energy management in the residential sector. This work addresses short-term forecasting (24-hour horizon) of the Spanish regulated tariff (PVPC) using the Temporal Fusion Transformer (TFT) architecture, designed to capture complex temporal dependencies while maintaining interpretability. Using real data from 2024, the performance of the proposed model is evaluated against LSTM networks and persistence-based methods. The experimental results demonstrate the superiority of the TFT, achieving an MAE of 30.63 €/MWh and an SMAPE of 0.1838, representing a 28.7 % reduction in error compared to the conventional LSTM architecture.

Keywords: electricity price forecasting (EPF); PVPC; temporal fusion transformer (TFT); deep learning; time series; energy management.

1. INTRODUCCIÓN

La descarbonización del sector eléctrico ha convertido la predicción de precios (EPF) en una competencia crítica para los sistemas de gestión energética del hogar (HEMS), que deben anticipar la alta volatilidad introducida por las renovables para optimizar el consumo [2]. En España, este desafío es central para la tarifa regulada (PVPC), indexada directamente al mercado mayorista.

Si bien el estado del arte en EPF ha evolucionado desde modelos econométricos hacia arquitecturas de *Deep Learning* (como LSTM), persisten limitaciones significativas: los métodos clásicos no capturan la complejidad no lineal del mix energético [4], mientras que las redes neuronales operan comúnmente como «cajas negras», careciendo de la explicabilidad necesaria para la toma de decisiones [1].

Para abordar esta brecha, este trabajo propone la aplicación del *Temporal Fusion Transformer* (TFT) [3] al mercado español. A diferencia de los modelos recurrentes estándar, el TFT emplea mecanismos de atención para aprender dependencias temporales a largo plazo manteniendo una interpretabilidad inherente. El objetivo de este estudio es validar mediante un primer modelo TFT si esta arquitectura presenta cierto potencial para superar en precisión a los modelos de referencia (LSTM).

2. DATOS Y METODOLOGÍA

2.1. CONJUNTO DE DATOS

Para este estudio se han utilizado datos reales del mercado eléctrico español obtenidos a través de la API de ESIOS (Red Eléctrica de España). La variable objetivo es el término

de facturación del PVPC con impuestos incluidos (*PVPC_billing_term_with_taxes*), ya que representa el coste final real para el consumidor doméstico. El *dataset* abarca registros horarios históricos desde junio de 2021 hasta diciembre de 2024. Se ha realizado una partición cronológica estricta para evitar el filtrado de información futura (*data leakage*):

- *Entrenamiento*: Del 1 de junio de 2021 hasta el 30 de junio de 2024.
- *Validación*: Del 1 de julio al 30 de septiembre de 2024 (3 meses).
- *Test*: Del 1 de octubre al 31 de diciembre de 2024 (3 meses).

Las variables de entrada se dividieron en dos categorías según su disponibilidad en tiempo real:

1. Conocidas en el futuro (*Known Inputs*): Variables de calendario (hora, día de la semana, mes, festivos nacionales) y tipos impositivos (IVA, IEE).
2. Observadas en el pasado (*Unknown Inputs*): Histórico de precios, tarifas de acceso (periodos valle/llano/pico), demanda real y generación por tecnologías (eólica, solar, nuclear, ciclo combinado). Estas variables solo están disponibles para el codificador (pasado) y no para el decodificador (futuro).

2.2. MODELOS Y CONFIGURACIÓN EXPERIMENTAL

Se han evaluado tres enfoques para la predicción con un horizonte de 24 horas (*Day-Ahead*):

1. *Baseline* de persistencia: Modelo ingenuo que asume que el perfil de precios de mañana será idéntico al de hoy: ($P_{t+24} = P_t$). Sirve como cota inferior de rendimiento.
2. *Long Short-Term Memory (LSTM)*: Red recurrente clásica configurada con 2 capas ocultas de 64 unidades y *dropout* del 0.1. Se entrenó minimizando el error absoluto medio (MAE). A diferencia del TFT, esta arquitectura trata todas las entradas de manera secuencial sin distinguir explícitamente entre variables estáticas o futuras conocidas.
3. *Temporal Fusion Transformer (TFT)*: La arquitectura propuesta se configuró con un tamaño de estado oculto de 64, 1 cabezal de atención y *QuantileLoss* para estimar la incertidumbre. El modelo utiliza una ventana de contexto (*encoder length*) de 168 horas (7 días) para predecir las siguientes 24 horas. El entrenamiento se realizó utilizando el optimizador Ranger y *Early Stopping* para prevenir el sobreajuste.

3. RESULTADOS

La Tabla 1 resume el desempeño de los modelos en el conjunto de test (último trimestre de 2024). El modelo TFT superó significativamente tanto al *baseline* como a la red LSTM en ambas métricas evaluadas.

Tabla 1. Comparativa de métricas de error en el conjunto de Test

Modelo	MAE (€MWh)	sMAPE (%)
Baseline (Persistencia)	38.10	32.19 %
LSTM (Recurrente)	43.00	25.65 %
TFT (Propuesto)	30.63	18.38 %

Mientras que la LSTM logró reducir el error porcentual (sMAPE) respecto a la persistencia, su error absoluto (MAE) fue mayor, indicando dificultades para manejar los picos de precios o cambios de tendencia abruptos. Por el contrario, el TFT logró una reducción del 28.7 % en MAE respecto a la LSTM y del 19.6 % respecto al *baseline*.

La Figura 1 muestra una predicción de 24 horas del modelo TFT frente a la realidad y al modelo de persistencia. Se observa cómo el modelo es capaz de anticipar correctamente la estructura diaria de precios, ajustándose a las rampas de subida y bajada mejor que los modelos tradicionales, gracias a la incorporación efectiva de las variables de calendario futuras.

4. CONCLUSIONES Y TRABAJO FUTURO

Este estudio preliminar valida la eficacia del *Temporal Fusion Transformer* para la predicción de precios en el mercado eléctrico español regulado (PVPC). Los resultados demuestran que el TFT no solo supera a las arquitecturas recurrentes clásicas (LSTM) en precisión (sMAPE 0.18 vs 0.25), sino que ofrece una arquitectura más robusta para integrar variables heterogéneas (series temporales pasadas y variables de calendario futuras).

La superioridad del TFT sugiere que los mecanismos de atención son más efectivos que la recurrencia simple para capturar las dependencias temporales complejas del mercado eléctrico actual, altamente influenciado por la volatilidad de las renovables.




Figura 1. Predicción de precios a 24h (TFT vs Realidad y *Baseline*) 15-12-2024, 00:00

Este trabajo representa una primera aproximación hacia un sistema de predicción avanzado. Gracias a que los TFT permiten incorporar *inputs* futuros conocidos (ej. demanda programada) y precios en contextos determinados, se abre una vía de investigación para desarrollar modelos que mejoren drásticamente la precisión de las redes neuronales tradicionales.

5. AGRADECIMIENTOS

Esta investigación forma parte del Proyecto de Cátedra Internacional sobre Inteligencia Artificial Fiable y Reto Demográfico dentro de la Estrategia Nacional de Inteligencia Artificial (ENIA), en el marco del Plan Europeo de Recuperación, Transformación y Resiliencia. Referencia: TSI-100933-2023-0001. Este proyecto está financiado por la Secretaría de Estado para la Digitalización y la Inteligencia Artificial y por la Unión Europea (Next Generation).

6. REFERENCIAS

1. Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable artificial intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>
2. Lago, J., Marcjasz, G., De Neyer, B., & Weron, R. (2021). Forecasting day-ahead electricity prices: A review of state-of-the-art algorithms, best practices and an open-access benchmark. *Renewable and Sustainable Energy Reviews*, 133, Artículo 110317. <https://doi.org/10.1016/j.rser.2020.110317>
3. Lim, B., Arık, S. Ö., Loeff, N., & Pfister, T. (2021). Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4), 1748-1764. <https://doi.org/10.1016/j.ijforecast.2021.03.012>
4. Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30(4), 1030-1081. <https://doi.org/10.1016/j.ijforecast.2014.08.008>